

基于一类支持向量机的盲元检测方法

张东阁^{1,2}, 傅雨田^{1,2}

- (1. 中国科学院红外探测与成像技术重点实验室, 上海 200083;
2. 中国科学院上海技术物理研究所, 上海 200083)

摘要: 利用无监督学习的一类支持向量机(One Class Support Vector Machine, OCSVM)和随机场景图像序列, 构造滚动更新的像元分类模型, 实现红外焦平面盲元的在线检测。根据正常像元和异常像元数量和灰度特征的差异, 以随机图像序列作为输入数据, 使用 OCSVM 建立单一类别的像元分类模型, 灰度变化的像元归为一类, 其他像元不属于此类。由于随机图像序列的滚动更新, OCSVM 模型及支持向量也随之更新。统计支持向量的频次, 高频次支持向量对应的像元聚为一类, 即为异常像元。以 320×256 中波红外图像序列为例, 说明了 OCSVM 模型进行盲元检测的过程, 检测结果与黑体定标的结果一致。基于随机场景和 OCSVM 模型的盲元检测方法摆脱了定标黑体的约束, 提高了盲元检测的灵活性。

关键词: 盲元检测; 支持向量机; 分类

中图分类号: TN216; O439 文献标志码: A DOI: 10.3788/IRLA201847.0404001

One class support vector machine used for blind pixel detection

Zhang Dongge^{1,2}, Fu Yutian^{1,2}

- (1. Key Laboratory of Infrared System Detection and Imaging Technology, Chinese Academy of Sciences, Shanghai 200083, China;
2. Shanghai Institute of Technical Physics of the Chinese Academy of Sciences, Shanghai 200083, China)

Abstract: One class support vector machine (OCSVM) was applied to classify the pixels of the infrared detectors, and it can detect the blind pixels by the random scenes. The blind pixel detection algorithms were reviewed in the beginning, and the imbalance distribution of the normal pixels and blind pixel was discussed in the following. The infrared image sequence was used to set up the OCSVM models and calculate the super sphere parameters, when the support vectors were represented by the Lagrangian coefficients. The OCSVM was an unsupervised method to cluster the pixels by the changing gray level and the random scenes. The super sphere model built by OCSVM would be refreshed by the updating image sequence, while the Lagrangian coefficients of the support vectors were recorded, so the blind pixels could be eventually classified by the statistic results of the preceding coefficients series. The mid-wave infrared 320×256 image sequence was taken as an example to illustrate the proposed method, and it got the same results as the black body calibration. It could conclude that the OCSVM used for the online modeling of the blind pixel detection of the infrared detectors is adaptive and self-refreshing, and it could improve the efficiency of the infrared system test.

Key words: blind pixel detection; support vector machine; classification

收稿日期: 2017-11-10; 修订日期: 2017-12-18

基金项目: 国家 863 计划(2015AA7015090, 2015AA7015097); 全球变化与海气相互作用专项任务(GASI-03-03-01-01); 中国科学院上海技术物理研究所创新基金(2014-CX25)

作者简介: 张东阁(1986-), 男, 助理研究员, 博士, 主要从事光学设计和机械设计方面的研究。Email: zhangdongge@mail.sitp.ac.cn

通讯作者: 傅雨田(1967-), 男, 研究员, 博士生导师, 博士, 主要从事红外光电系统总体技术方面的研究。Email: yutianfu@mail.sitp.ac.cn

0 引言

红外焦平面是红外辐射能量到电子学信号转换的核心器件,由于生产工艺的不足和半导体材料的缺陷,再加上使用过程中环境应力的影响^[1],红外焦平面组件不可避免地出现盲元。盲元不能探测目标辐射能量的变化,在图像序列中表现为黑白或闪烁噪点,严重时带来虚假目标的干扰。国内外学者研究了多种检测算法,对盲元进行识别和定位。白俊奇等设计了基于灰度阈值的盲元检测方法^[2],以面源黑体作为辐射源,手动调节红外图像的动态范围,通过目视判读不同增益条件下图像的差异,从而确定盲元的位置。类似的还有姚勤芬等提出的双参考源检测方法^[3]。利用灰度的特征分布参数进行盲元检测的方法^[4-7]被提出:在定标黑体辐照下,正常像元灰度的均值和标准差服从正态分布,而盲元灰度的分布参数游离在正常区间之外。以此作为判据,检测红外图像的盲元分布。黄曦等研究了一种基于动态场景的盲元检测方法^[8],将红外图像中的亮点和暗点作为被测目标,通过迭代修正的背景预测模型,从而发现和识别盲元。冷寒冰等提出了时域多帧累加和模糊中值滤波的盲元检测方法^[9],结合盲元的灰度特征,在一定程度上避免了点目标和盲元的混淆。栗宇路等设计了一种根据红外图像灰度分布的时空特征进行盲元检测的方法^[10],在随机场景下,正常像元的灰度值会随场景变化,盲元的灰度则表现出在空域上的奇异性和时域上的恒定性。根据两者的时空特征差异,通过多帧图像判断盲元的分布。

随着工作时间的累积,红外焦平面受高低温循环和开关机等因素的影响,再加上振动、冲击和过饱和和辐照等环境应力的作用,焦平面的潜在缺陷逐渐被激发,一些像元变为新的盲元,个别像元出现闪烁或跳变,最终表现为红外焦平面的盲元分布偏离初始状态,此时就需要重新标定盲元的分布。基于黑体定标的盲元检测方法利用大口径面源黑体作为辐射源,在停机期间对红外焦平面的灰度或响应特性进行标定,从而确定盲元的数量和分布。基于场景的盲元检测方法不需要专门的定标黑体,利用当前场景作为辐射源,通过图像处理估计盲元的分布,具有较大的灵活性和便利性。

文中提出了一种基于随机场景的盲元检测方法,利用一类向量机(One Class Support Vector Machine, OCSVM)的无监督分类特性,以随机场景图像序列作为输入数据,建立在线更新的盲元检测模型。首先介绍了红外焦平面的响应特性,根据正常像元和异常像元灰度和数量分布的特征差异,分析了单一类别分类模型的原理和必要性;然后给出了 OCSVM 模型进行盲元检测的算法和关键参数分析;最后以 320×256 中波红外图像序列为例进行了说明。

1 红外焦平面的响应特性

红外焦平面的盲元是指响应率低于一定值或者噪声高于一定值的像元,包括死像元和过热像元^[11]。死像元在图像上表现为暗点,过热像元在图像上表现为亮点,同时也可能存在个别闪烁或跳变的像元。

在增益和积分时间设置正确的条件下,正常像元对输入光强的响应近似 S 曲线的上升段,如图 1 中曲线 a 段,图像灰度不超过预定的动态范围。随着场景的变化,输出的图像灰度也随之变化。

盲元的响应率小于曲线 a 段,类似于图 1 的曲线 b 和 c,输出的灰度值几乎不随场景发生变化,闪烁或跳变像元介于两者之间。

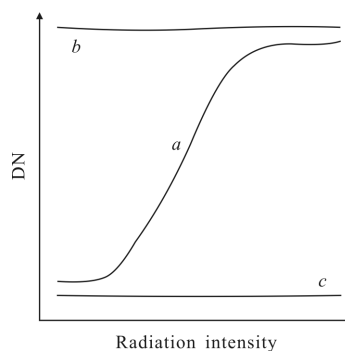


图 1 红外焦平面的像元响应率模型
Fig.1 Responsivity model of IRFPA pixels

红外焦平面的盲元检测可以看作是一个分类问题或异常检测问题,如图 2 的像元分类模型所示,根据像元的灰度或响应率差异,按照预定的分类规则,先从全部像元中筛选出不能正常工作的故障像元,再从故障像元中区分过热像元和死像元,完成像元的分类。




图 2 像元分类模型

Fig.2 Classification model of pixels inspection

常用的分类方法有 Naive Bayes、Artificial Neural Net、Decision Tree 等，这些模型都需要已知类型的样本数据进行建模和训练，而且模型的泛化能力受样本数据的质量影响较大。

针对红外焦平面的盲元检测问题，事先不知道盲元的分布和数量，即缺少盲元分布的先验知识，而且不同场景下像元的灰度分布不尽相同。唯一能够确定的信息是正常像元占大多数，盲元比较少，两者分布不平衡。因此，盲元检测问题排除了上述基于已知样本类型的有监督分类模型和方法。

2 一类支持向量机的原理

支持向量机 (Support Vectors Machine, SVM) 是一种基于统计学习理论的建模方法，利用核函数将特征向量映射到高维空间，求解凸二次规划问题得到全局最优的模型参数，避免了传统建模方法存在局部极小值和维度组合膨胀的不足，常用于小样本条件下回归分析和模式识别等问题。

SVM 分类的实质是寻找一个最优分类边界，即在保证分类精度的前提下，使两类样本尽可能分开，实现分类间隔最大化。SVM 模型是一种有监督的分类算法，建模时需要事先确定样本的类别。

根据前述分析，红外焦平面的像元检测问题缺少盲元的分布和数量的先验信息，而且样本分布不均衡，不是常规的有监督分类问题，因此不能使用标准 SVM 模型。

一类支持向量机 (One Class SVM, OCSVM) 是标准 SVM 模型的改进形式^[2]，它不依赖已知类别的样本数据，通过高斯核函数将样本点投影到高维空间，寻找一个包含给定样本的最小化超球体模型，实现无监督的分类。

针对样本数据 $\{x_1, x_2, \dots, x_n\}$ ， n 是样本数量， $\varphi(x_i)$

是将样本点映射到高维空间的函数，则单一类别分类问题的目标函数可以定义为确定一个超球体的球心位置 c ，使半径 R 最小。

$$\min R^2 + C \sum_i \xi_i \quad (1)$$

约束条件是 $\|\varphi(x_i) - c\|^2 \leq R^2 + \xi_i$ ， $\xi_i \geq 0$ 。式中： ξ_i 是松弛变量； C 是惩罚因子； $i=1, 2, \dots, n$ 。

公式(1)的对偶问题可表示为：

$$\max \sum_{i=1}^n \alpha_i K(x_i, x_i) - \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j K(x_i, x_j) \quad (2)$$

约束条件是 $\sum_i \alpha_i = 1$ ， $0 \leq \alpha_i \leq C$ ， $i=1, 2, \dots, n$ 。

利用拉格朗日法求解问题公式(2)，得到公式(1)的最优解。

根据每个样本 x_i 对应的拉格朗日系数 α_i 的取值，样本 x_i 与超球体的位置关系有三种：(1) $\alpha_i=0$ ，样本点在超球体内部，距离球心比较近；(2) $0 < \alpha_i < C$ ，样本点在超球体的内表面，构成了超球体的支持向量；(3) $\alpha_i=C$ ，样本点在超球体的外部，也构成了超球体的支持向量。

满足条件(2)和(3)的样本点是超球体的支持向量，分布在超球体边界的内外两侧或边界上，确定了超球体的球心位置和半径参数。

满足条件(2)和(3)的拉格朗日系数 α_i 大于零，且大于条件(1)的系数 α_i 。满足条件(1)的系数 α_i 是绝对值接近零的小数，通常做法是设置一定的门限或阈值，直接将其置零。

OCSVM 模型对异常值很灵敏，可用于外点、新颖点或异常点的检测。姚富光等利用 OCSVM 模型建立正常物料的颜色分布模型^[13]，对物料传输线上的异物进行在线检测。

为区分新鲜鸡蛋和非新鲜鸡蛋，林颢等利用 OCSVM 模型对鸡蛋的近红外光谱数据进行建模^[14]，解决了新鲜鸡蛋和非新鲜鸡蛋样本比例失衡的问题，而且分类效果优于标准 SVM 模型。

3 盲元检测算法

针对红外焦平面的盲元检测问题，利用 OCSVM 模型建立单一类别的分类模型，将灰度随场景变化的像元归为一类，其他像元不属于此类，从而区分正常像元和盲元。然后再从盲元中区分过热像元和死像元。

以随机场景生成的图像序列作为输入数据，建

立以 OCSVM 模型表示的超球体模型,超球体的支持向量是一部分正常工作的像元和盲元,正常工作的像元靠近超球体的内边界,盲元分布在超球体的外边界。绝大多数正常工作的像元分布在靠近超球体的内部,不作为支持向量。

随着成像场景的变化,红外图像的灰度分布随着改变,OCSVM 模型表示的超球体半径和位置也随之变化,超球体的支持向量也随之更新。

利用上述差异,统计随机场景图像序列建立的 OCSVM 模型支持向量的频次差异,从而发现异常像元。

详细的算法流程如图 3 所示,以 $m \times n$ 图像作为输入数据,即输入一个 $\{m \times n \times 1, i\}$ 的图像序列,其中 $m \times n$ 是红外图像的规格, i 是图像的帧计数。

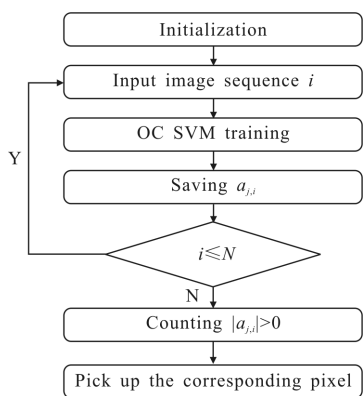


图 3 算法流程图

Fig.3 Flow chart of the proposed method

选择高斯核函数,训练 OCSVM 模型,输出每个像元的拉格朗日系数 $\alpha_{j,i}$,然后统计每个像元在图像序列中拉格朗日系数 $\alpha_{j,i}$ 大于零的频次,标记对应的像元。

图 3 中 i 是样本序号, N 是总样本数量,代表总的图像帧数。 j 是 $m \times n \times 1$ 序列化图像的像元序号,即 $\alpha_{j,i}$ 是第 i 帧图像第 j 像素的拉格朗日系数。

OCSVM 模型的训练还需要解决以下三个问题:

(1) 核函数参数的设置。SVM 模型常用的核函数有多项式核函数、RBF 核函数、高斯核函数等,通常根据试算的结果选择最佳的核函数及参数。以盲元检测问题为例,经过比较分析,选择高斯核函数的均值是 0,方差是 500。

(2) 最佳样本容量 N 的选择。为确定最佳的样本数量,以 50 帧图像为起点,按照二分法成倍增减图像序列长度,比较了 10、20、50、100、200 帧的检测结果。在 10~200 帧范围内,检测结果几乎相同。

如果图像序列的相关性小,场景变化显著,理论上只需要 3 帧图像即可区分正常像元和异常像元。如果图像序列之间的相关性较大,极端情况是完全相同的场景,无论图像序列长度是多少,都不能实现预定的像元检测结果。

(3) 算法的计算复杂度。OCSVM 的建模和训练包括核函数计算和二次规划问题求解等步骤,时间复杂度较高。为减少建模时间,加快图像序列的处理速度,借助并行化的概念,设计了多个 OCSVM 模型分段对图像序列进行建模,最后汇总每个 OCSVM 模型的拉格朗日系数计算结果。

为适应样本数据的更新,有学者提出了 OCSVM 模型的增量学习算法^[15-16],利用矩阵分解和已有的支持向量计算结果,将新的样本加入模型的训练,实现 OCSVM 模型的在线更新和学习,减少 OCSVM 模型训练的计算量。

图 3 的盲元检测算法的输入数据是完整的一帧图像,根据当前的图像计算每个像元的拉格朗日系数 $\alpha_{j,i}$,不必使用上一帧图像的计算结果,同时新的图像序列加入 OCSVM 模型,需要计算当前数据对应的支持向量及拉格朗日系数 $\alpha_{j,i}$,即每一帧图像都是一个新的训练样本,与增量式学习算法解决的问题不同,因此盲元检测的 OCSVM 模型不必也不能使用增量式学习算法。

4 盲元检测实例

4.1 盲元的检测

以 320×256 中波红外相机的外景图像序列为例,利用上述方法对其进行像元分类。红外相机在各增益和积分时间配置下均能正常工作,图 4 是红外相机在镜头遮挡下输出的图像。




图 4 中波红外 320×256 图像

Fig.4 Mid wave infrared 320×256 image

第一步是从全部像元中区分正常像元和盲元,

图 5 是 OCSVM 模型对第 10 帧图像前 200 个像元的建模结果。

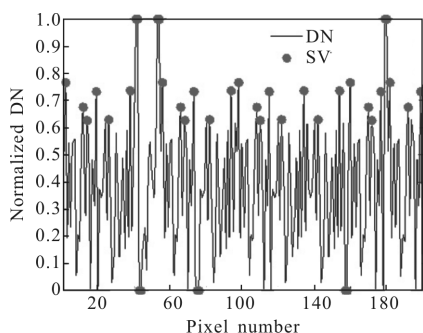


图 5 OCSVM 模型基于第 10 帧图像数据的支持向量

Fig.5 Support vectors of the OCSVM model based on the tenth frame image

图 5 中曲线代表了红外图像的归一化灰度,即输入的样本序列,实心圆点标记了当前状态下超球体的支持向量(图例是 SV)。这些支持向量所代表的像元既有相对 DN 值为零的死像元,也有相对 DN 值为 1 的过热像元或饱和像元,也可能有一部分是正常像元。未做标记的像元都不是支持向量。

表 1 是标号 40~45 像元根据 200 帧图像的拉格朗日系数 $\alpha_{j,i}$ 计算结果,行标号 1~200 是图像的帧计数。

表 1 OCSVM 模型拉格朗日系数 $\alpha_{j,i}$ 的计算结果
Tab.1 Results of Lagragian coefficients $\alpha_{j,i}$ of the OCSVM models

No.	40	41	42	43	44	45
1	2.4E-18	5.3E-19	0.025	0.025	0.025	1.5E-18
2	0.025	4.6E-19	0.025	0.025	5.4E-19	5.2E-19
3	1.5E-19	0.025	0.025	0.025	8.5E-19	1.1E-19
4	4.1E-19	4.8E-20	0.025	0.025	0.025	1.9E-19
5	1.6E-19	1.2E-19	0.025	0.025	6.9E-19	0.025
...
198	1.9E-19	2.5E-18	0.025	0.025	3.9E-18	4.7E-19
199	0.025	2.4E-19	0.025	0.025	1.8E-18	0.025
200	4.4E-21	0.025	0.025	0.025	1.1E-18	4.3E-19

表 1 中大部分像元的拉格朗日系数接近零,对应着靠近超球体球心位置的非支持向量。

根据表 1 的第 1 行数据,在第 1 帧图像中,第 42、

43、44 等像元的拉格朗日系数大于零,都是 OCSVM 模型的支持向量,确定了超球体的边界。在第 2 帧图像,第 40、42、43 等像元的拉格朗日系数大于零,都是新 OCSVM 模型的支持向量,确定了新的超球体边界。

随着图像序列的更新,正常像元的灰度不断变化,对应的超球体形状和位置也随之变化,第 2 帧图像数据建立的 OCSVM 模型的支持向量不再是第 1 帧图像数据建立的 OCSVM 模型的支持向量。

以此类推,第 $i+1$ 帧图像数据建立的 OCSVM 模型的支持向量不再是第 i 帧建立的 OCSVM 模型的支持向量。随着输入图像数据的滚动更新,OCSVM 模型及其支持向量随之更新,界定了对应的超球体模型的边界。

如图 1 所示,过热像元和死像元等盲元的灰度特征不同于正常像元的灰度特征。在 OCSVM 模型更新的过程中,盲元始终具有较大的拉格朗日系数,始终是 OCSVM 超球体模型的外部支持向量。

经过多帧图像的迭代更新,统计拉格朗日系数的频次,拉格朗日系数不断变化的像元是正常像元,每次都有较大拉格朗日系数的像元就是异常像元,从而将两者区分开。根据表 1 数据,判定第 42 和 43 像元是异常像元。

4.2 过热像元的检测结果

过热像元和死像元之间有显著的灰度差异,两者之间的区分是一个简单的二分类问题。

根据 4.1 节盲元检测的结果,OCSVM 模型从所有像元中区分出了盲元,再次利用 OCSVM 模型,即可从盲元中区分出过热像元和死像元。

根据黑体定标的结果,320×256 中波红外图像的第 1 行第 42 列和第 1 行第 43 列都是死像元,对应表 1 的第 42 和 43 像元,其他各处也有相同的检测结果。

4.3 对不同积分时间和增益的检测结果

根据上述分析,利用 OCSVM 模型对不同积分时间和增益配置下的随机图像序列进行检测,比较拉格朗日系数和检测结果的差异。

表 2 是不同增益和积分时间下中波红外图像的拉格朗日系数分布,在不同积分时间和增益中,盲元和正常像元的拉格朗日系数几乎没有变化,而在同一种图像序列中,盲元和正常像元的拉格朗日系数具有显著差异。

表 2 不同增益和积分时间图像数据建立 OCSVM 模型的拉格朗日系数差异

Tab.2 Lagragian coefficients of the OCSVM models based on the image generated by the variant gains and exposure time

(a) 增益 0×60 , 积分时间 0.4 ms 条件下图像对应的 OCSVM 模型拉格朗日系数

(a) Lagragian coefficients of the OCSVM model based on the image generated by the gain 0×60 and exposure time 0.4 ms

	450	451	452	453	454
1	4.4E-18	3.3E-19	0.096 2	0.096 2	2.1E-18
2	0.096 2	2.1E-19	0.096 2	4.1E-19	5.2E-19
3	5.6E-18	0.0962	0.096 2	2.8E-19	7.9E-18
4	3.3E-19	4.6E-19	0.096 2	0.096 2	2.4E-18
5	2.6E-19	2.5E-19	0.096 2	8.4E-18	0.096 2
...
198	1.5E-19	2.5E-18	0.096 2	3.9E-18	5.7E-18
199	0.096 2	9.4E-19	0.096 2	7.8E-19	0.096 2
200	1.4E-17	5.8E-18	0.096 2	4.5E-18	4.3E-19

(b) 增益 0×80 , 积分时间 0.25 ms 条件下图像对应的 OCSVM 模型拉格朗日系数

(b) Lagragian coefficients of the OCSVM model based on the image generated by the gain 0×80 and exposure time 0.25 ms

	450	451	452	453	454
1	4.8E-18	0.0962	0.096 2	0.096 2	1.5E-18
2	0.096 2	6.3E-18	0.096 2	5.4E-19	8.2E-19
3	4.4E-18	0.0962	0.096 2	8.5E-19	1.1E-19
4	6.4E-19	2.4E-19	0.096 2	0.096 2	1.9E-19
5	1.1E-17	3.5E-18	0.096 2	6.9E-19	0.096 2
...
198	5.1E-19	2.5E-18	0.096 2	4.9E-19	9.1E-19
199	0.096 2	9.4E-19	0.096 2	7.8E-18	0.096 2
200	1.8E-17	4.4E-18	0.096 2	6.3E-18	1.3E-18

(c) 增益 0×80 , 积分时间 0.1 ms 条件下图像对应的 OCSVM 模型拉格朗日系数

(c) Lagragian coefficients of the OCSVM model based on the image generated by the gain 0×80 and exposure time 0.1 ms

	450	451	452	453	454
1	1.8E-18	4.2E-19	0.096 2	1.0E-18	1.5E-17
2	7.2E-18	0.096 2	0.096 2	3.1E-18	1.2E-18
3	3.1E-18	1.6E-18	0.096 2	1.1E-18	4.1E-19
4	0.096 2	2.2E-18	0.096 2	6.5E-18	1.2E-18
5	1.5E-18	3.2E-19	0.096 2	6.1E-19	0.096 2
...
198	5.2E-18	5.2E-18	0.096 2	0.096 2	4.7E-19
199	0.096 2	7.3E-18	0.096 2	3.8E-18	0.096 2
200	9.6E-19	2.8E-18	0.096 2	1.2E-18	4.3E-19

根据表 2 的数据,调整红外相机的增益和积分时间参数,只要红外图像的灰度级不超过预定的动态范围,OCSVM 模型都能从中区分盲元和正常像元。

4.4 计算时间分析

在 Core i7-4790+32G RAM 硬件平台上,使用 Matlab 2011b + LIBSVM 3.2.0 软件配置,建立了像元检测的程序原型,测试 OCSVM 模型对 320×256 图像序列的处理效果。

OCSVM 模型的核函数计算和二次规划求解拉格朗日系数是制约处理速度的主要因素,在单核配置下,单帧 320×256 图像完成一次 OCSVM 建模耗时约 $100 \sim 120 \text{ s}$ 。

OCSVM 对每个像素的处理是相对独立的过程,因此可以采用并行化方法,同时采用多个 OCSVM 模型对图像序列进行分割处理,最后汇总每个 OCSVM 模型的计算结果。

根据上述分析,在 Matlab 中采用 4 路并行配置,单帧图像耗时约 $50 \sim 70 \text{ s}$ 。完成一次像元检测的时间与样本图像序列的数量和质量有关,详见第 3 节(2)最佳样本容量分析。

5 结 论

为提高红外焦平面盲元检测的灵活性,解决盲元分布随工作时间累积发生漂移的问题,文中提出了利用 OCSVM 模型和随机场景图像序列进行盲元检测的方法。

OCSVM 模型建立了灰度随场景变化像元的单一类别分类模型,通过随机场景图像序列的滚动更新,OCSVM 模型及其支持向量也随之更新,统计不同场景下 OCSVM 模型支持向量的频次差异,高频次支持向量对应的像元就是盲元。

基于 OCSVM 模型的盲元检测方法不依赖定标黑体,检测结果只取决于像元自身的响应特性。这个过程可以反复在线进行,有利于及时发现红外焦平面的响应特性和盲元分布随时间的漂移和变化。

基于 OCSVM 和随机场景图像序列的盲元检测方法,与红外焦平面的类型和参数无关,适应性强,可用于多种类型红外焦平面的检测。

参考文献:

[1] Hao Lichao, Huang Aibo, Lai Canxiong, et al. Discussion of

- reliability analysis on IRFPAs by bad pixel [J]. *Infrared and Laser Engineering*, 2016, 45(5): 0504004. (in Chinese)
- [2] Bai Junqi, Jiang Yiliang, Zhao Chunguang, et al. Blind pixel detection algorithm for infrared focal plane array detector[J]. *Infrared Technology*, 2011, 33(4): 233–240. (in Chinese)
- [3] Yao Qinfen, Gu Guohua. A new algorithm of blind pixel detection for IRFPA [J]. *Infrared Technology*, 2012, 34(8): 441–443. (in Chinese)
- [4] Zhang Honghui, Luo Haibo, Yu Xinrong, et al. Blind pixel detection algorithm for IRFPA by applying pixel's characteristics histogram analysis [J]. *Infrared and Laser Engineering*, 2014, 43(6): 1807–1811. (in Chinese)
- [5] Yan Fei, Hou Qingyu. Algorithm of blind pixel detection based on multi statistical characteristic abnormality[J]. *Infrared and Laser Engineering*, 2014, 43(2): 454–457. (in Chinese)
- [6] Zhang Qiaozhou, Gu Guohua, Chen Qian, et al. Real time blind pixel detection and compensation technology based on two point parameters and self-adaptive window [J]. *Infrared Technology*, 2013, 35(3): 139–145. (in Chinese)
- [7] Kan Bohan, Yin Jinjian, Li Lingjie, et al. IR blind pixels detection algorithm based on adjustable threshold window [J]. *Laser & Infrared*, 2014, 44(8): 949–952. (in Chinese)
- [8] Huang Xi, Zhang Jianqi, Liu Delian. Algorithm of blind pixels adaptive detection and compensation for infrared image [J]. *Infrared and Laser Engineering*, 2011, 40(2): 370–376. (in Chinese)
- [9] Leng Hanbing, Gong Zhendong, Xie Qingsheng, et al. Adaptive blind pixel detection and compensation for IRFPA based on fuzzy median filter [J]. *Infrared and Laser Engineering*, 2014, 44(3): 821–826. (in Chinese)
- [10] Li Yulu, Su Lan, Chen Daqian, et al. Adaptive blind pixel detection algorithms based on stepwise search strategy [J]. *Infrared Technology*, 2016, 38(6): 457–460. (in Chinese)
- [11] GB/T 17444–2013 The technical norms for measurement and test of characteristic parameters of infrared focal plane arrays[S]. Beijing: China Standards Press, 2014. (in Chinese)
- [12] Pan Zhisong, Chen Bin, Miao Zhimin, et al. Overview of study on one class classifiers [J]. *Acta Electronica Sinica*, 2009, 37(11): 2496–2503. (in Chinese)
- [13] Yao Fuguang, Zhong Xianxin, Tang Xiangyang, et al. Mechanism and implementation of one class support vector machine in fast foreign real time recognition [J]. *Optics and Precision Engineering*, 2009, 17(4): 937–942. (in Chinese)
- [14] Lin Hao, Zhao Jiewen, Chen Quansheng, et al. Identification of egg freshness using near infrared spectroscopy and one class support vector machine algorithm [J]. *Spectroscopy and Spectral Analysis*, 2010, 30(4): 929–932. (in Chinese)
- [15] Zheng Guansheng, Wang Jiandong, Gu Bin, et al. Analysis of one class incremental support vector machine [J]. *Journal of Nanjing University of Aeronautics and Astronautics*, 2015, 47(1): 113–118. (in Chinese)
- [16] Wang Hongbo, Zhao Guangzhou, Qi Donglian, et al. Fast incremental learning method for one class support vector machine [J]. *Journal of Zhejiang University (Engineering Science)*, 2012, 46(7): 1327–1332. (in Chinese)